



LISBON
SCHOOL OF
ECONOMICS &
MANAGEMENT
UNIVERSIDADE DE LISBOA

MESTRADO
MATEMÁTICA FINANCEIRA

TRABALHO FINAL DE MESTRADO
DISSERTAÇÃO

**ANÁLISE CRÍTICA DO VAR DAS PRINCIPAIS
EMPRESAS DO SETOR INDUSTRIAL COTADAS NA
EURONEXT LISBON**

DANIEL ALEXANDRE LOPES MARTINS

OUTUBRO – 2018



LISBON
SCHOOL OF
ECONOMICS &
MANAGEMENT
UNIVERSIDADE DE LISBOA

MESTRADO
MATEMÁTICA FINANCEIRA

TRABALHO FINAL DE MESTRADO
DISSERTAÇÃO

**ANÁLISE CRÍTICA DO VAR DAS PRINCIPAIS
EMPRESAS DO SETOR INDUSTRIAL COTADAS NA
EURONEXT LISBON**

DANIEL ALEXANDRE LOPES MARTINS

ORIENTAÇÃO: PROFESSOR NUNO SOBREIRA

OUTUBRO – 2018

Abstract

This research compares the accuracy of different models of conditional volatility of the *GARCH* family to predict 1-day *VaR* (*Value at Risk*) with the stock returns of four companies of the Portuguese industrial sector and establishes a chronology of the periods of highest volatility that generated *VaR* violations. Asymmetric conditional volatility models such as *EGARCH* and *GJR-GARCH* under a leptokurtic distribution generally obtained the best performances. It was also possible to conclude the existence of similarity in the type of events that affected the volatility of the securities of the analyzed companies.

Keywords: Value at Risk (VaR); GARCH; Conditional volatility models; Volatility forecast; Industrial sector; Euronext Lisbon

Resumo

Esta investigação compara a capacidade de diferentes modelos de volatilidade condicional da família *GARCH* em prever o *VaR* (*Value at Risk*) a 1 dia da rentabilidade das ações de quatro empresas do setor industrial português, e estabelece uma cronologia dos períodos de maior volatilidade que foram tão extremos que geraram violações do *VaR*. Os modelos de volatilidade condicional assimétricos como o *EGARCH* e o *GJR-GARCH* sob uma distribuição leptocúrtica obtiveram, na generalidade, os melhores desempenhos. Foi também possível concluir a existência de similaridade no tipo de acontecimentos que afetaram a volatilidade dos títulos das empresas analisadas.

Palavras-chave: Value at Risk (VaR); GARCH; Modelos de volatilidade condicional; Previsão de volatilidade; Setor industrial; Euronext Lisbon

Agradecimentos

Ao Professor Nuno Sobreira, pelo apoio, pela disponibilidade e pelo aconselhamento durante o desenvolvimento do trabalho.

Aos meus Pais, por todo o apoio e dedicação, e claro, à Ane.

ÍNDICE

1	Introdução	1
2	Revisão de literatura.....	3
3	Metodologia	6
3.1	Modelos de volatilidade	6
3.1.1	GARCH.....	6
3.1.2	IGARCH.....	8
3.1.3	EGARCH	8
3.1.4	GJR-GARCH	9
3.2	Distribuição dos erros.....	9
3.3	Cálculo do VaR.....	11
3.4	Backtesting do <i>VaR</i>	13
4	Amostra e resultados	15
4.1	Análise dos resultados.....	15
4.2	Análise cronológica.....	17
4.2.1	Altri	17
4.2.2	Cimpor.....	20
4.2.3	Mota-Engil	22
4.2.4	Navigator.....	24
5	Conclusão.....	26
6	Bibliografia	28
7	Anexos.....	31
7.1	Anexo A – Resultados das previsões do <i>VaR</i>	31
7.2	Anexo B – Evolução da volatilidade.....	39

ÍNDICE DE TABELAS E FIGURAS

TABELAS

TABELA 1- Previsão VaR a 99% de confiança para a Altri	31
TABELA 2- Previsão VaR a 99% de confiança para a Cimpor	32
TABELA 3- Previsão VaR a 99% de confiança para a Mota-Engil.....	33
TABELA 4- Previsão VaR a 99% de confiança para a Navigator	34
TABELA 5- Previsão VaR a 95% de confiança para a Altri	35
TABELA 6- Previsão VaR a 95% de confiança para a Cimpor	36
TABELA 7- Previsão VaR a 95% de confiança para a Mota-Engil.....	37
TABELA 8- Previsão VaR a 95% de confiança para a Navigator	38

FIGURAS

FIGURA 1- Evolução da volatilidade diária da ação da Altri.	39
FIGURA 2- Evolução da volatilidade diária da ação da Cimpor.	39
FIGURA 3- Evolução da volatilidade diária da ação da Mota-Engil.....	40
FIGURA 4- Evolução da volatilidade diária da ação da Navigator.	40

1 Introdução

Ao longo das últimas décadas, assistiu-se a um crescimento persistente da volatilidade dos preços dos ativos financeiros. De acordo com Bruni et al. (1988), o aumento da volatilidade deveu-se sobretudo a fatores como a desregulamentação das instituições e mercados financeiros, inovações financeiras ao nível dos produtos, serviços e mercados, como os derivados e algoritmos de *trading*, bem como ao desenvolvimento tecnológico, que permitiu grandes avanços a nível de *hardware*, *software* e comunicações.

O aumento da volatilidade nos mercados financeiros globais juntamente com um conjunto de desastres financeiros, destacando-se o *crash* bolsista de 1987, foram o catalisador para um período particularmente intenso, no que concerne à investigação e desenvolvimento de modelos de gestão de risco por parte de instituições financeiras, reguladores e académicos.

Em resposta a essa desafiante época surgiu o *Value-at-Risk (VaR)*, uma ferramenta estatística na área da gestão de risco de *portfolios*, que pode ser definida grosseiramente como a maior perda expetável que pode ocorrer numa carteira de ativos para um dado período temporal.

Um dos objetivos deste trabalho é comparar a capacidade de diferentes modelos de volatilidade da família *GARCH (Generalized Autoregressive Conditional Heteroskedasticity)* em prever o *VaR* a 1 dia. O outro objetivo deste trabalho é estabelecer uma cronologia dos períodos de maior volatilidade identificando aqueles retornos que foram de tal forma extremos que geraram violações do *VaR*. Pretende-se relacionar essas violações do *VaR* com acontecimentos globais ou específicos de cada

empresa incluída na amostra e que, em princípio, estarão intimamente relacionados com a ocorrência dessas observações extremas.

Naturalmente que é possível fazer este exercício para inúmeros ativos financeiros cotados nos vários mercados bolsistas. Optou-se por analisar apenas um pequeno grupo de empresas de modo a conseguir estabelecer uma cronologia mais detalhada para cada uma delas. Assim, para este trabalho, foram usados os retornos de ações de quatro empresas cotadas na *Euronext Lisbon* que atuam no setor industrial: a Altri, a Navigator, a Mota-Engil e a Cimpor.

A próxima secção irá fazer uma revisão da literatura mais relevante para este trabalho e apresentar de forma breve as principais conclusões dos autores dos respetivos trabalhos. Na secção 3 serão apresentados os modelos de volatilidade e as suas distribuições, a metodologia do cálculo do *VaR* e a estratégia de *backtesting* dos modelos. Na secção 4 identifica-se o período temporal da amostra e será feita uma análise descritiva dos dados das empresas que compõem a amostra. Depois será realizada uma análise detalhada aos resultados do estudo empírico e também uma análise gráfica, estabelecendo uma cronologia dos principais eventos que causaram violações do *VaR*. Na secção 5 poderão ser encontradas as conclusões e na secção 6 a literatura que serviu de referência à realização do presente trabalho. E finalmente, na secção 7, poderão ser encontrados os anexos.

Por fim, destaco que neste trabalho utilizou-se os cálculos para as previsões da volatilidade efetuados por Rui Louro, ex-aluno do Mestrado em Econometria Aplicada e Previsão (MEAP) e atual aluno do Programa de Doutoramento em Matemática Aplicada

à Economia e Gestão (PDMAEG), a quem se agradece a disponibilização destes mesmos dados e o esclarecimento de dúvidas.

2 Revisão de literatura

Os econometristas sempre demonstraram preocupação em realizar uma correta captura das oscilações futuras dos dados financeiros, mais precisamente em prever a volatilidade dos retornos de ativos financeiros.

Introduzido por Engle (1982), o modelo *ARCH* (*Autoregressive Conditional Heteroskedasticity*), foi pioneiro entre os modelos existentes à época na caracterização da dependência temporal da volatilidade, quando a maior parte dos modelos mais populares nesse tempo assumiam a volatilidade como um valor constante ao longo do tempo. O modelo *ARCH* tem algumas limitações, como a dificuldade em providenciar “boas” estimativas dos parâmetros, quando é selecionada uma ordem elevada. Note-se que muitas vezes é necessário assumir uma ordem elevada para descrever as propriedades dinâmicas associadas a essa mesma volatilidade. Consequentemente, Bollerslev (1986) propôs uma extensão do *ARCH*, o modelo *GARCH*, que comparado ao *ARCH*, é uma alternativa mais parcimoniosa (Poon e Granger, 2003). Muita investigação foi dedicada ao melhoramento destes modelos, tendo sido desenvolvidas uma série de extensões do modelo *GARCH*. Como a estimação da volatilidade futura constitui um elemento fundamental para o cálculo do *VaR*, esta classe de modelos de volatilidade tem sido amplamente utilizada no seu cálculo.

Desenvolvido em finais da década de 1980, pela divisão de investimento do banco norte-americano *JP Morgan*, o *VaR* rapidamente se tornou uma ferramenta

fulcral no setor financeiro, tanto para propósitos de gestão de risco como regulatórios. Em particular, o Comité de Supervisão Bancária de Basileia, em 1996, impôs às instituições financeiras como bancos e fundos de investimento requisitos de capital baseados em estimativas do *VaR*.

Com a forte popularização do *VaR*, a comunidade científica rapidamente se debruçou sobre este tema, existindo uma vasta investigação na área e não se pretende fazer nesta revisão de literatura um levantamento exaustivo de todos os artigos existentes. Pretende-se destacar apenas alguns dos que se consideram mais relevantes para o tema deste trabalho. Giot e Laurent (2003a) calcularam previsões diárias do *VaR* para posições curtas e longas em quatro índices de ações. Concluíram que o modelo *APARCH* utilizando uma distribuição *t-Student* assimétrica obteve o melhor desempenho. Posteriormente, Giot e Laurent (2003b) confirmaram as conclusões anteriores, mas desta vez estudaram o mercado norte-americano de matérias primas. Angelidis et al. (2004) examinaram o desempenho de uma extensa família de modelos *GARCH* no cálculo do *VaR* diário de cinco índices de ações. Concluíram que os modelos com distribuições leptocúrticas produziam as melhores previsões, que o tamanho da amostra é importante para a precisão da previsão e que a especificação da média condicional é irrelevante. Bali e Theodossiou (2007) combinaram a distribuição *t-Student* generalizada assimétrica com dez modelos da família *GARCH*, e argumentaram que o *TS-GARCH* e *EGARCH*, tiveram o melhor desempenho geral, ao estimarem com precisão o *VaR*. Sener et al. (2012) propuseram um novo modelo de classificação e um teste estatístico complementar para investigar o desempenho dos vários métodos de previsão do *VaR*. Os resultados indicaram que os modelos assimétricos, tais como o *CAViaR* assimétrico e o *EGARCH* foram os mais bem-

sucedidos, e que o desempenho dos modelos não depende inteiramente se são paramétricos ou não paramétricos, mas sim se conseguem modelar a assimetria dos dados eficazmente. Dendramis et al. (2014) sublinharam que os modelos *GARCH* e *EGARCH* combinados com as versões assimétricas das distribuições *t-Student* e *GED* (*Generalized Error Distribution*) constituem excelentes ferramentas na modelação do *VaR*, tendo produzido resultados suficientemente robustos em diferentes mercados financeiros. Abad e Benito (2013) investigaram o desempenho de vários modelos de volatilidade condicional, analisando quatro índices europeus, dentro de dois períodos: um estável e outro volátil. Os resultados evidenciaram que modelos da família *GARCH* combinados com distribuições assimétricas e de caudas pesadas produziram as melhores previsões. Os resultados deste artigo estão em concordância com Hansen e Lunde (2005) e Níguez (2008).

3 Metodologia

Recorda-se que, neste trabalho, pretende-se comparar a capacidade preditiva de diferentes modelos da família *GARCH* em termos de *VaR* e, simultaneamente, identificar as datas das observações extremas que geraram violações do *VaR* em cada empresa e interpretá-las. Com esses objetivos em mente vamos descrever, sucintamente, os modelos *GARCH* que foram usados neste trabalho, as distribuições do termo de erro consideradas, a fórmula de cálculo do *VaR* a partir destes modelos e a forma como o *VaR* é validado nas secções 3.1, 3.2, 3.3 e 3.4, respetivamente.

3.1 Modelos de volatilidade

3.1.1 GARCH

Seja $r_t = \ln\left(\frac{P_t}{P_{t-1}}\right)$ a rentabilidade (em tempo contínuo) do período $t - 1$ para t , onde P_t é o preço do ativo no momento t .

Parte-se do pressuposto que a série r_t pode ser dividida em duas componentes, uma previsível de acordo com a informação passada e outra imprevisível:

$$r_t = E(r_t | F_{t-1}) + u_t,$$

onde F_{t-1} denota a informação disponível de todas as rentabilidades até ao momento $t - 1$, $E(\bullet)$ é o valor esperado e u_t é o termo de erro, ou seja, a componente que representa a parte imprevisível na rentabilidade dos ativos.

Engle (1982) propôs o modelo *ARCH*(q) para u_t :

$$u_t = \sigma_t \varepsilon_t,$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 u_{t-1}^2 + \cdots + \alpha_q u_{t-q}^2,$$

onde ε_t é uma sequência de variáveis aleatórias independentes e identicamente distribuídas com média zero e variância unitária; σ_t^2 é a variância condicional de r_t ; $\alpha_0 > 0$; e $\alpha_i \geq 0$ para $i = 1, \dots, q$ de modo a garantir que $\sigma_t^2 > 0$. A ideia base deste modelo é o facto de a série u_t ser não autocorrelacionada, mas dependente ao nível dos segundos momentos, e a dependência de u_t poder ser descrita por uma simples função quadrática dos desfasamentos temporais, de modo a captar o denominado fenómeno de *volatility clustering*¹ presente nas séries temporais financeiras. No entanto, este modelo, em muitas situações, para conseguir estimar adequadamente a evolução da variância condicional necessita de vários desfasamentos, o que levanta problemas de estimação dos parâmetros, quando assumida uma ordem elevada.

Bollerslev (1986) propôs uma generalização do *ARCH*, o modelo *GARCH*(p, q):

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i u_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2,$$

onde $\alpha_0 > 0$, $\alpha_i \geq 0$ para $i = 1, \dots, q$, $\beta_j \geq 0$ para $j = 1, \dots, p$ e $\sum_{i=1}^q \alpha_i + \sum_{j=1}^p \beta_j < 1$ como condição de estacionaridade de segunda ordem da variância.

O modelo *ARCH*, só considera para a previsão do próximo momento o termo do erro ao quadrado, desfasado nos vários períodos temporais. Para além dessa componente, o modelo *GARCH* introduziu outra componente, a própria variância condicional desfasada, o que veio permitir ter uma estrutura mais parcimoniosa que o *ARCH*, na medida em que evita a adoção de demasiados desfasamentos.

¹ Fenómeno notado por Mandelbrot (1963) em séries temporais financeiras, que explica, referindo-se à volatilidade do preço de ativos, que fortes (baixas) variações são normalmente seguidas de fortes (baixas) variações em ambos os sentidos. Este fenómeno tende a revelar alguma persistência temporal.

3.1.2 IGARCH

De acordo com Engle e Bollerslev (1986) e Chou (1988), as estimativas dos parâmetros do modelo *GARCH* em várias aplicações empíricas apresentam valores tais que $\sum_{i=1}^q \hat{\alpha}_i + \sum_{j=1}^p \hat{\beta}_j \approx 1$, ou seja, em que há uma forte suspeita da existência de uma raiz unitária no modelo *GARCH*. Tal implica que estamos perante um fenómeno de volatilidade muito persistente. Neste sentido, Engle e Bollerslev (1986) propuseram então o modelo *IGARCH*(p, q):

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i u_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2,$$

$$\sum_{i=1}^q \alpha_i + \sum_{j=1}^p \beta_j = 1,$$

onde $\alpha_0 > 0$, $\alpha_i \geq 0$ para $i = 1, \dots, p$, e $\beta_j \geq 0$ para $j = 1, \dots, q$.

3.1.3 EGARCH

Uma limitação dos modelos apresentados anteriormente é o facto de assumirem que os choques positivos e negativos (“boas” e “más” notícias) geram o mesmo comportamento na volatilidade, quando na literatura financeira, é conhecido que o preço de um ativo financeiro responde de forma diferente a um choque negativo ou um choque positivo. Este fenómeno é conhecido como efeito assimétrico.

De modo a ultrapassar esta limitação dos modelos apresentados anteriormente, Nelson (1991) propôs o *GARCH* exponencial, ou o *EGARCH*(p, q). Aqui, a variância condicional é obtida por:

$$\ln(\sigma_t^2) = \alpha_0 + \sum_{i=1}^q \left(\alpha_i \frac{|u_{t-i}|}{|\sigma_{t-i}|} + \delta_i \frac{u_{t-i}}{\sigma_{t-i}} \right) + \sum_{j=1}^p \beta_j \ln(\sigma_{t-j}^2).$$

Em contraste com o modelo *GARCH*, não existem restrições ao nível dos parâmetros, dado que a transformação logarítmica garante a não negatividade da volatilidade. O parâmetro δ_i permite captar o efeito assimétrico. Se $\delta_i = 0$, então uma “boa” notícia, $u_{t-i} > 0$, tem o mesmo efeito na volatilidade que uma “má” notícia, $u_{t-i} < 0$. Caso contrário, se $\delta_i \neq 0$, existe efeito assimétrico. A presença do *leverage effect*² pode ser testada pela hipótese de que $\delta_i < 0$.

3.1.4 GJR-GARCH

Glosten et al. (1993) sugeriram o modelo *GJR-GARCH(p,q)* para modelar o efeito assimétrico sendo que este surge como alternativa ao *EGARCH*. A variância condicional deste modelo, pode ser escrita como:

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i u_{t-i}^2 + \sum_{i=1}^q \delta_i S_{t-i} u_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2,$$

onde $\alpha_0 > 0$, $\alpha_i \geq 0$ para $i = 1, \dots, p$, $\beta_j \geq 0$ para $j = 1, \dots, q$ e $\alpha_i + \delta_i \geq 0$ para $i = 1, \dots, p$. S_{t-i} é uma variável *dummy* que assume o valor 1 se u_{t-i} for negativo, e 0 caso contrário. Tal como no modelo anterior, o choque é assimétrico se $\delta_i \neq 0$ e é simétrico se $\delta_i = 0$ mas, ao contrário do *EGARCH*, o *leverage effect* ocorre se $\delta_i > 0$.

3.2 Distribuição dos erros

A distribuição dos erros dos modelos da classe *GARCH*, ε_t , tem um papel fundamental na estimação do modelo de volatilidade. Um dos pressupostos inicialmente assumidos por Engle (1982) no modelo *ARCH* foi que a série dos erros segue uma distribuição normal, com média 0 e variância unitária. A função densidade de probabilidade (FDP) da distribuição normal é dada por:

² Efeito identificado por Black (1976), que implica que a volatilidade se torna mais elevada em resposta a “más” notícias (choques negativos) do que a “boas” notícias (choques positivos).

$$(1) f(\varepsilon_t) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{\varepsilon_t^2}{2}\right).$$

Muitas vezes, a distribuição normal aplicada a séries de retornos apresenta várias limitações, como o facto de não conseguir modelar convenientemente as caudas pesadas sendo que esta é uma regularidade empírica sistematicamente observada neste tipo de dados. Para superar as limitações da distribuição normal, Bollerslev (1987) propôs a utilização da distribuição *t-Student* para o comportamento dos erros. A FDP é determinada por:

$$(2) f(\varepsilon_t) = \frac{\Gamma(\frac{\nu+1}{2})}{\sqrt{\nu\pi} \Gamma(\frac{\nu}{2})} \left(1 + \frac{\varepsilon_t^2}{\nu}\right)^{-\left(\frac{\nu+1}{2}\right)},$$

onde $\Gamma(\nu) = \int_0^\infty y^{\nu-1} e^{-y} dy$ é uma função gama, e ν são os graus de liberdade, o que permite definir a espessura das caudas da distribuição.

Outra distribuição que tem sido considerada pela literatura financeira como alternativa à distribuição normal é a *Generalized Error Distribution (GED)*. Tem como FDP:

$$(3) f(\varepsilon_t) = \frac{\kappa e^{-0.5\left|\frac{x-\alpha}{\beta}\right|^\kappa}}{2^{1+\kappa-1} \beta \Gamma(\kappa-1)},$$

onde α, β e κ representam respetivamente os parâmetros de posição, escala e forma.

Têm sido vários os investigadores a introduzir esquemas de distribuições mais gerais que permitam capturar de forma mais eficaz as regularidades empíricas observadas em séries de retornos. Destaca-se a proposta de Fernandez e Steel (1998) que apresentou uma distribuição assimétrica com FDP de uma variável aleatória ε_t , de acordo com (1-3), representada como:

$$f(\varepsilon_t|\xi) = \frac{2}{\xi + \xi^{-1}} [f(\xi\varepsilon_t) H(-\varepsilon_t) + f(\xi^{-1}\varepsilon_t) H(\varepsilon_t)],$$

onde $\xi \in \mathbb{R}^+$ e $H(\varepsilon_t)$ é uma função de Heaviside. ξ representa o parâmetro de assimetria na FDP.

3.3 Cálculo do VaR

De acordo com Jorion (2000, p. 22), o *VaR* é definido como a máxima perda esperada numa carteira de ativos, num determinado horizonte temporal e com um determinado nível de significância. Em termos estatísticos, o *VaR* corresponde ao quantil da distribuição das rentabilidades da carteira, sendo dado por:

$$P(\Delta R \leq -VaR) = \alpha,$$

onde ΔR representa a variação do valor da carteira de ativos no horizonte temporal definido.

O cálculo das previsões do *VaR* a 1 dia, VaR_{t+1} , será feito com base nas previsões para os retornos e para a volatilidade dos retornos do dia seguinte à última observação da amostra de estimação.

Na vasta literatura de séries temporais financeiras, o valor esperado condicional dos retornos é considerada uma componente pouco explicativa do modelo. Além disso, a média da maior parte das séries de retornos apresenta valores muito próximos de zero. Portanto, neste trabalho vai-se considerar por simplicidade que este é, de facto, nulo seguindo também a linha de raciocínio de Angelidis et al. (2004). Então, tem-se:

$$E(r_t|F_{t-1}) = 0.$$

Naturalmente, conclui-se que, de acordo com esta hipótese, as previsões para os retornos futuros são sempre nulas. Por outro lado, e seguindo a prática da literatura anterior, vão-se considerar os modelos mais parcimoniosos da classe *GARCH*, ou seja, com as ordens mais baixas, $p = q = 1$. Nesse caso, a variância condicional, segundo o modelo *GARCH(1,1)*, é dada por:

$$\hat{\sigma}_{t+1}^2 = \hat{\alpha}_0 + \hat{\alpha}_1 \hat{u}_t^2 + \hat{\beta}_1 \hat{\sigma}_t^2.$$

No caso do *IGARCH(1,1)*:

$$\hat{\sigma}_{t+1}^2 = \hat{\alpha}_0 + \hat{\alpha}_1 \hat{u}_t^2 + \hat{\beta}_1 \hat{\sigma}_t^2,$$

com $\hat{\alpha}_1 + \hat{\beta}_1 = 1$.

Para o *EGARCH(1,1)*:

$$\ln(\hat{\sigma}_{t+1}^2) = \hat{\alpha}_0 + \hat{\alpha}_1 \frac{|\hat{u}_t|}{|\hat{\sigma}_t|} + \hat{\delta}_1 \frac{\hat{u}_t}{\hat{\sigma}_t} + \hat{\beta}_1 \ln(\hat{\sigma}_t^2).$$

E por fim, a variância condicional, segundo o modelo *GJR-GARCH(1,1)*, para $t + 1$ obtém-se por:

$$\hat{\sigma}_{t+1}^2 = \hat{\alpha}_0 + \hat{\alpha}_1 \hat{u}_t^2 + \hat{\delta}_1 S_t \hat{u}_t^2 + \hat{\beta}_1 \hat{\sigma}_t^2.$$

Tendo em conta os pressupostos anteriores, é possível provar que a previsão do *VaR* a 1 dia, é dada por (Tsay, 2010, p. 293-294):

$$VaR_{t+1} = F_\alpha \hat{\sigma}_{t+1}^2,$$

onde F_α é o quantil de ordem α da distribuição da série dos erros, sendo que as possibilidades são $N(0,1)$, *t-Student*, *GED* ou as versões assimétricas destas distribuições e α foi definido como 0.01 e 0.05. Os parâmetros das distribuições *t*-

Student e *GED* (assim como as versões assimétricas) são estimados em cada período de tempo pelo algoritmo encarregue da modelação *GARCH* do *package* estatístico utilizado. Ou seja, para cada período de tempo t , as características das distribuições alteram-se.

3.4 Backtesting do *VaR*

Apesar da ampla utilização e aceitação do *VaR* como ferramenta de gestão de risco e dos modelos *GARCH* como modelos de volatilidade, nem sempre conseguem produzir previsões fiáveis, que podem ter como causa erros amostrais, modelos desapropriados aos dados em análise e má especificação dos mesmos. Assim, o *VaR* só é útil se conseguir prever os futuros riscos com precisão. De modo a verificar se os resultados obtidos a partir dos cálculos do *VaR* são consistentes e fiáveis, o modelo deve ser testado através de uma técnica conhecida por *backtesting*. O *backtesting* é um procedimento estatístico em que as perdas reais são comparadas com as previsões do *VaR*. Quando o modelo se encontra perfeitamente calibrado, o número de observações que excedem as previsões do *VaR* (violações do *VaR* ou exceções) devem estar em conformidade com o nível de confiança, como por exemplo, 5% do total de observações serem exceções para um nível de confiança de 95%. No caso de existirem exceções em demasia, o modelo está a “subestimar” o risco. Contrariamente, no caso de existir muito poucas exceções, o modelo está a “sobrestimar” o risco. Em ambas as situações, a alocação de capital será ineficiente.

Um método de averiguar a precisão do modelo é analisar a proporção de falhas, isto é, a proporção de vezes em que o *VaR* estimado é excedido num determinado

período de tempo. Definindo $N = \sum_{t=0}^T I_{t+1}$ como o número de dias numa amostra T em que a perda da carteira foi superior à respetiva estimativa do VaR , ou seja:

$$I_{t+1} = \begin{cases} 1, & r_{t+1} < VaR_{t+1} \\ 0, & r_{t+1} \geq VaR_{t+1} \end{cases},$$

onde N é o número de exceções observadas e N/T é a proporção de falhas. Assumindo que o modelo está calibrado, Jorion (2000) refere que esta proporção deve originar um valor não enviesado de α à medida que a dimensão da amostra aumenta.

4 Amostra e resultados

Na aplicação empírica, serão utilizadas as rentabilidades, calculadas a partir de valores diários de fecho das ações de quatro das principais empresas do setor industrial que compõem a *Euronext Lisbon*: a Altri, a Navigator, a Mota-Engil e a Cimpor. Os valores das cotações foram recolhidos através da base de dados da *Euronext* (www.euronext.com).

Para a estimação dos modelos $GARCH(1,1)$, $IGARCH(1,1)$, $EGARCH(1,1)$ e $GJR-GARCH(1,1)$ recorreu-se ao software estatístico *R*, mais concretamente ao *package Rugarch*, usando na sua previsão uma “janela móvel” (*rolling window*) de 1000 observações, que inicialmente, estimou os modelos com as observações de 27 de janeiro de 2009 a 13 de dezembro de 2012, para prever a observação de 14 de dezembro de 2012, ou seja, a observação número 1001. De seguida incluiu-se a observação 1001 na amostra de estimação (constituída agora da observação 2 até à observação 1001) para prever a observação 1002 e assim sucessivamente, até ao dia 27 de junho de 2017.

4.1 Análise dos resultados

Os resultados das previsões do *VaR* podem ser encontrados no anexo A. As tabelas 1-8 contêm informação sobre o número de violações alvo, o número de violações geradas pelo modelo bem como a proporção de falhas. As distribuições presentes nas tabelas, quando precedidas da letra “s” referem-se às suas versões assimétricas. Os resultados das tabelas levaram a conclusões interessantes, com implicações importantes na escolha do modelo apropriado para o cálculo do *VaR*.

A hipótese de a série dos erros assumir uma distribuição normal produziu diferentes resultados para os dois níveis de significância utilizados. Para um nível de

significância de 1%, a proporção de falhas é superior a 1% em todas as empresas para todos os modelos, ocorrendo um caso em que o número de violações atuais é igual ou superior ao dobro das violações alvo, sendo esse caso a Cimpor. Para um nível de significância de 5%, os resultados foram mais assertivos, estando no geral os modelos mais próximos do número alvo de violações, como no caso do *EGARCH* para a Altri e Mota-Engil, sendo que para esta última empresa, quando introduzida a assimetria na distribuição, o modelo *EGARCH* consegue atingir o número de violações alvo.

Como já tínhamos visto, a suposição de a série de erros assumir uma distribuição normal nem sempre produz as melhores previsões, sendo necessário recorrer a distribuições de caudas pesadas, como a distribuição *t-Student*. Para esta distribuição e para um nível de significância de 1%, as previsões do *VaR* para a maioria dos modelos foram satisfatórias. O modelo *EGARCH* para as empresas Altri e Navigator conseguiu ter uma percentagem de violações atuais igual à violação alvo. Para o outro nível de significância considerado, de 5%, os resultados não foram tão satisfatórios como para o nível de significância de 1%, apesar de alguns modelos também terem atingido o número de violações alvo, como o caso do modelo *IGARCH* para a Navigator, e também do *EGARCH* para a Mota-Engil, sendo que para este modelo foi sob a hipótese de assimetria na distribuição *t-Student*.

Os resultados obtidos usando a outra distribuição de caudas pesadas considerada, *GED*, também foram satisfatórios para um nível de significância de 1%. A maior parte dos modelos sob esta distribuição atingiu um número muito próximo ou mesmo o número alvo de violações. Para um nível de significância de 5%, em linha com os resultados da distribuição *t-Student*, os resultados das previsões foram menos bons, apesar de também haver modelos bem-sucedidos, como o *GARCH* para a empresa

Navigator, que ficou uma violação abaixo do número de violações alvo, e quando assumida a versão assimétrica da *GED*, atinge esse número de violações alvo.

4.2 Análise cronológica

Nesta secção será feita uma análise cronológica que mostra graficamente a evolução da volatilidade de cada empresa ao longo do período em análise, relacionando-a mais precisamente com acontecimentos que estão intimamente ligados a períodos de maior volatilidade nas ações das empresas, que levaram a que 75% ou mais dos modelos de volatilidade condicional apontassem para uma violação do *VaR*, para um nível de significância de 5%. As notícias sobre esses acontecimentos foram pesquisadas no histórico do Jornal de Negócios (www.jornaldenegocios.pt). Os valores da volatilidade obtidos nos gráficos, que podem ser encontrados no anexo B, são apresentados em percentagem e de uma forma anualizada através da multiplicação do desvio-padrão das rentabilidades diárias pela raiz quadrada de 250 (número médio de sessões bolsistas num ano).

4.2.1 Altri

Começa-se por destacar as seguintes datas onde ocorreram violações do *VaR*, para a Altri (Figura 1 do anexo B):

- A 3 e 5 de abril de 2013, onde a proximidade da decisão do Tribunal Constitucional sobre um conjunto de normas do Orçamento do Estado de 2013, que em caso de chumbo, poderia representar um rombo superior a mil milhões de euros nas contas públicas, comprometendo a execução orçamental e originar uma crise política com a demissão do governo português;

- A 20 e 21 de junho de 2013, existiu a iminência da Reserva Federal retirar os estímulos à economia norte-americana ainda antes do final do ano. Note-se que os Estados Unidos da América são um dos principais importadores de papel produzido pelo mercado português. Esse período ficou ainda marcado pela instabilidade política na Grécia, onde um dos três partidos que compoñham o governo, anunciou o abandono dos seus membros da coligação devido a divergências sobre as políticas seguidas pelo primeiro-ministro;
- A 3 de julho de 2013, semana em que ocorreram as demissões dos ministros das finanças e dos negócios estrangeiros, originando uma crise política em Portugal, que fez aumentar os receios dos investidores, sobretudo motivados pela possibilidade de Portugal não conseguir sair do programa de ajustamento em junho de 2014, tal como planeado, e que viesse a precisar de um segundo resgate;
- A 10 de março de 2014, o BPI *Equity Research* cortou a recomendação atribuída à Altri de “*buy*” para “*neutral*”. Esta reavaliação, segundo a casa de investimentos, é justificada pela quebra perspetivada para o segundo semestre de 2014, onde era esperada uma descida dos preços da pasta de papel, refletindo o impacto de novas unidades produtoras de pasta de papel na América Latina;
- A 24 de março de 2014, dia marcado pela situação vivida entre a Ucrânia e a Rússia pela posse do território da Crimeia, onde a crise se intensificou depois de as forças russas invadirem uma base militar ucraniana na Crimeia. A ameaça de um conflito militar pressionou bastante as bolsas europeias. Ocorreu também uma quebra inesperada da produção industrial na China, que ameaçou a meta de

crescimento traçada para aquela economia, sendo que a China é o maior produtor mundial de pasta de papel;

- A 8 e 10 de julho de 2014, na semana onde teve início a grave crise financeira do Banco Espírito Santo, que atirou o PSI-20 para a maior queda desde há um ano, e também com fortes repercussões nas bolsas europeias;
- A 24 de junho de 2015, viveu-se o impasse das negociações entre a Grécia e o Eurogrupo, depois de terem sido rejeitadas algumas propostas gregas. Os credores queriam garantias de mais reformas a nível financeiro e económico de forma a desbloquear a última tranche da ajuda externa;
- A 24 de agosto de 2015, a bolsa de Xangai teve uma queda de 8,5% e contagiou as restantes bolsas mundiais. Os receios dos investidores estiveram relacionados com o fraco desempenho de alguns indicadores macroeconómicos da economia chinesa, como o crescimento do PIB, produção industrial, vendas a retalho e exportações. As matérias primas também foram atingidas, com as empresas do setor industrial a serem fortemente penalizadas. O petróleo renovou mínimos de 6 anos;
- A 14 de abril de 2016, um *research* do banco de investimento Haitong cortou a recomendação sobre as ações da Altri de “*neutral*” para “*sell*” e reviu em baixa as estimativas para o EBITDA de 2016, com uma redução de 30%. A decisão foi justificada com a queda dos preços da pasta de papel;
- A 24 junho de 2016, dia seguinte ao referendo sobre a permanência do Reino Unido na União Europeia, com os resultados a serem favoráveis aos eurocéticos.

O PSI-20 chegou a negociar em mínimos de 20 anos e as ações da Altri encerraram a descer mais de 6%.

4.2.2 Cimpor

Destacam-se as seguintes datas, onde ocorreram violações do *VaR*, para a Cimpor (figura 2 do anexo B):

- A 3 e 6 de junho de 2013, a Cimpor viveu um período de instabilidade, devido às renúncias dos administradores Luis Sequeira Martins e Manuel Blanc, que integravam o conselho de administração da empresa desde 1987 e 2001, respetivamente. Estas renúncias surgiram numa altura em que a cimenteira continuava a sofrer alterações no âmbito da oferta pública de aquisição lançada pela InterCement, do grupo Camargo Corrêa;
- A 23 de janeiro de 2014, a Cimpor foi condenada pelas autoridades brasileiras a pagar uma coima de 170 milhões e à alienação de ativos correspondentes a 25% da sua capacidade de produção instalada no Brasil. Esta condenação surge na sequência da investigação de supostas condutas alusivas à prática de infrações à ordem económica nos mercados do cimento e betão pronto no Brasil por diversas empresas do setor;
- A 5 de novembro de 2014, face à continua descida do crude, a organização dos países exportadores de petróleo (OPEP), reviu em baixa a sua estimativa de consumo para os próximos anos, sendo que a Cimpor tem operações em países cuja economia tem grande dependência desta matéria-prima. Nesse período, a Comissão Europeia reviu em baixa o crescimento para a Zona Euro, incluindo Portugal;

- A 17 de agosto de 2015, a Cimpor apresentou, no primeiro semestre desse ano, prejuízos de 7 milhões de euros, quando um ano antes tinha tido perdas de 200 mil euros. Este resultado foi muito ditado pelo clima de incerteza político e económico vivido no Brasil, onde a empresa tem uma das suas principais operações. Esta situação levou ao fecho de fábricas e à redução da sua equipa no Brasil;
- A 14 de dezembro de 2015, o preço do petróleo desceu, chegando a negociar perto de mínimos de 2009, em consequência de os inventários de crude nos Estados Unidos terem disparado;
- A 8 de junho de 2016, a Cimpor suspendeu, temporariamente, os contratos de parte dos trabalhadores em funções na unidade de produção de clínquer em Loulé. A empresa justificou esta decisão com base na redução de 50% das vendas de cimento nos últimos cinco anos, que voltaram a apresentar sinais de abrandamento no 1º semestre de 2016;
- A 18 de novembro de 2016, depois da Cimpor ter apresentado um prejuízo de 590 milhões de euros entre janeiro e setembro, um valor mais do que 13 vezes maior do que o resultado líquido negativo de 43 milhões de euros verificado no período homólogo. A cimenteira argumentou que os resultados financeiros foram penalizados pelo efeito cambial adverso ao longo do ano.

4.2.3 Mota-Engil

Destacam-se as seguintes datas, onde ocorreram violações do *VaR*, para a Mota-Engil (figura 3 do anexo B):

- A 4 de março de 2013, quando o programa de ajustamento a Portugal esteve em debate no Eurogrupo, onde o país tentava obter uma flexibilização nas metas do défice, que permitiria diluir os cortes na despesa, apesar da resistência da troika, que confrontava o governo português com os maus resultados da execução orçamental. Outros eventos que pressionaram a bolsa portuguesa e as ações da Mota-Engil nesse período foram o impasse vivido em Itália para a formação do Governo, depois de as eleições terem sido inconclusivas e o abrandamento no setor dos serviços na China;
- A 3 de julho de 2013, as demissões dos ministros das finanças e dos negócios estrangeiros atiraram as bolsas para baixo, sobretudo pelos receios que Portugal não conseguisse vir a sair do programa de ajustamento em junho de 2014, tal como planeado, e que viesse a precisar de um 2º resgate. Nessa sessão, o PSI-20 perdeu mais de 5% e as ações da Mota-Engil mais de 9%;
- Em 26 de fevereiro de 2014, o maior acionista da Mota-Engil e a própria construtora anunciaram a venda de quase 17% do capital, numa operação que visou alargar a base de investidores e reforçar a liquidez e “*free float*” dos títulos. A venda das ações não foi bem-recebida pelos investidores, o que levou as ações da empresa a sofrerem a maior queda desde julho, penalizada pelo desconto a que as 34,3 milhões de ações foram vendidas;

- A 5 de janeiro de 2015, os investidores estiveram com os olhos postos na situação política da Grécia, onde as sondagens para as eleições legislativas indicavam a vitória do Syriza, um partido de extrema esquerda eurocético. Perante este cenário, a possibilidade de a Grécia abandonar a Zona Euro tornava-se cada vez mais real. A queda do preço petróleo também penalizou fortemente os mercados, onde se inclui as ações da Mota-Engil, pois os mercados exportadores da construtora estão muito dependentes desta matéria-prima;
- A 16 de junho de 2015, a Mota-Engil caiu mais de 8%, depois de ter anunciado uma oferta de obrigações para os pequenos investidores num montante de 70 milhões de euros, com uma taxa de juro bastante menos atrativa do que em emissões anteriores. Ainda nesse dia, o BESI cortou a avaliação da Mota-Engil de 4,00 para 2,6 euros por ação. O novo preço alvo é justificado pelo cenário macroeconómico em África que podia afetar a construção no curto prazo;
- A 18 de janeiro de 2016, a Mota-Engil teve períodos de grande volatilidade, voltando a ser fortemente penalizada pela descida do preço do petróleo, que chegou a atingir mínimos de 12 anos. A queda da cotação desta matéria prima afastou os investidores devido as preocupações em relação a Angola, economia fortemente dependente do petróleo e uma das principais operações da construtora;
- A 16 de setembro de 2016, as ações da empresa voltaram a passar por períodos de volatilidade depois de o presidente da cimenteira ter afirmado não ter

confiança para investir em Portugal, face à retração que houve nos últimos anos nas áreas que a empresa opera, como a construção e os serviços.

4.2.4 Navigator

Destacam-se as seguintes datas, onde ocorreram violações do *VaR*, para a Navigator (figura 4 do anexo B):

- A 15 de março de 2013, o anúncio de uma queda inesperada do índice de confiança dos consumidores norte-americanos contribuiu para o pessimismo nas bolsas americanas, que teve efeito contágio nos mercados europeus. As ações da Navigator foram penalizadas, sendo que os Estados Unidos são o principal mercado de exportação da papeleira;
- A 3 de julho de 2013, as demissões dos ministros das finanças e dos negócios estrangeiros, atiraram a bolsa nacional para baixo, onde as ações da Navigator tiveram uma queda de 6%. A crise política em Portugal gerada pelas demissões dos ministros das finanças e dos negócios estrangeiros fizeram tombar o PSI-20 para níveis de 2010, com os investidores a recear que Portugal se tornasse numa nova Grécia;
- A 3 de março de 2014, intensificou-se o conflito entre a Ucrânia e a Rússia pelo território da Crimeia, depois de a Rússia se recusar a retirar os militares daquela região, penalizando o comportamento dos principais índices bolsistas europeus, com o PSI-20 a ser atingido também, e as ações da Navigator a perderem mais de 2%;
- A 15 de maio de 2014, numa altura em que se aproximavam as eleições legislativas gregas, uma sondagem mostrou que os partidos que suportavam o

Governo de Atenas estavam a perder apoio, em especial o PASOK, o que fez reacear uma nova crise política na Grécia;

- A 16 de outubro de 2014, um *research* do Caixa Banco de Investimento ressalvou que os resultados do 3º trimestre deveriam refletir os normais impactos sazonais ao nível dos custos e das margens de exploração, pelo que decidiram manter o preço-alvo da empresa em 3,80 euros;
- A 26 de maio de 2015, as ações da Navigator estiveram sob alguma pressão depois de a Semapa ter anunciado o lançamento de uma oferta pública de aquisição (OPA), na modalidade de oferta de troca. Em causa estava a compra da Semapa por si própria e a oferta de ações da Navigator em troca;
- A 24 de agosto de 2015, Navigator avançou com uma oferta para reembolso antecipado de 200 milhões, que consistiu na compra antecipada dos títulos de dívida emitidos em 2013, pagando o “par” mais um prémio, que, contudo, não chegou aos preços de mercado;
- A 20 de janeiro de 2016, ficou marcado pelos receios em torno do abrandamento da economia chinesa, depois dos dados oficiais da China terem mostrado que o PIB do país cresceu 6,8% no último trimestre do ano, e 6,9% no conjunto de 2015 – o ritmo de crescimento mais lento dos últimos 25 anos. As bolsas europeias afundaram para mínimos de 15 anos, com o PSI-20 a acompanhar a tendência;
- Em 13 de setembro de 2016, um *research* do BPI atirou as ações da Navigator para uma queda superior a 6%, depois do corte de recomendação de “*buy*” para “*neutral*” e de descer o preço-alvo de 3,80 euros para 3,40 euros. O BPI

justificou o corte na avaliação e na recomendação com o facto de as importações dos fabricantes asiáticos estarem a acelerar nos próximos meses e o facto de os fabricantes não integrados da Europa terem vindo a cortar os preços devido à descida do preço da pasta de papel.

5 Conclusão

Os modelos de volatilidade condicionada utilizados no presente trabalho revelaram-se adequados e suficientemente robustos para a realização de previsão do *VaR*, de quatro das principais empresas cotadas do setor industrial da *Euronext Lisbon*. Para além da utilização de modelos mais clássicos como o *GARCH*, a introdução de modelos de volatilidade condicionada assimétricos como o *EGARCH* e o *GJR-GARCH* veio-se a revelar bastante satisfatória, na medida que permitiram apresentar resultados consistentes de acordo com um dos fenómenos mais conhecidos das séries temporais financeiras, o *leverage effect*, conseguindo assim modelar o diferente comportamento da volatilidade em resposta a uma “boa” ou “má” notícia.

A utilização de diferentes funções de distribuição para os erros do *GARCH* também se revelou importante, sendo que as distribuições *t-Student* e *GED* obtiveram, de um modo geral, melhor desempenho do que a distribuição normal. Este resultado pode ser justificado pelo facto de as séries dos retornos financeiros se caracterizarem pelo excesso de curtose positivo, significando distribuições com caudas pesadas e maior probabilidade de captar com sucesso os eventos extremos na amostra, como por exemplo, o período de crise financeira das dívidas soberanas da Zona Euro, que afetou sobretudo os países do sul da Europa.

Os resultados permitem também aferir que existem similaridades nos tipos de acontecimentos que afetaram a volatilidade dos títulos das empresas do setor industrial analisadas e que levaram a violações do *VaR*, com particular destaque para as notícias relacionadas com as crises políticas e económicas geradas pela crise financeira das dívidas soberanas. Outros tipos de acontecimentos que também importa destacar foram as notícias intra-setor como a descida do preço das matérias-primas inerentes aos ramos de atividade de cada empresa analisada, bem como as suas apresentações de resultados financeiros e das notas de *research* elaboradas por sociedades gestoras de ativos e bancos de investimento.

Importa salientar que existem algumas limitações intrínsecas a este trabalho, como o fato dos dados históricos puderem não fornecer boas previsões, isto é, os dados históricos têm comportamentos diferentes dependendo dos períodos. Se o período for relativamente estável, o *VaR* assume um valor baixo minimizando o risco. Caso contrário, se o período em analisado for volátil, o *VaR* assume um valor mais elevado.

6 Bibliografia

Abad, P. and Benito, S. (2013). A detailed comparison of value at risk estimates. *Mathematics and Computers in Simulation*, 94(1), 258-276.

Angelidis, T., Benos, A. and Degiannakis, S. (2004). The use of GARCH models in VaR estimation. *Statistical Methodology*, 1(1), 105-128.

Bali, T. and Theodossiou, P. (2007). GT-VaR approach with alternative GARCH models. *Annals of Operations Research*, 151(1), 241–267.

Black, F. (1976). Studies of stock price volatility changes, *Proceedings of the 1976 Meetings of the Business and Economics Statistics Section, American Statistical Association*, 177-181.

Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity, *Journal of Econometrics*, 31(3), 307–327.

Bollerslev, T. (1987). A conditional time series model for speculative prices and rates of returns, *Review of Economics and Statistics* 69(3), 524-554.

Bruni, F., E. Fair, D. and O'Brien, R. (1996). *Risk Management in Volatile Financial Markets*, 1^a Ed. London: Kluwer Academic Publishers.

Chou, R. (1988). Volatility Persistence and Stock Valuations: Some Empirical Evidence Using GARCH, *Journal of Applied Econometrics*, 3(4), 279-94.

Dendramis, Y., Spungin, G. and Tzavalis, E. (2014). Forecasting VaR models under Different Volatility Processes and Distributions of Return Innovations. *Journal of Forecasting*, 33(7), 515–531.

Engle, R. F. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation, *Econometrica*, 50(4), 987-1008.

Engle, R. F. and Bollerslev, T. (1986). Modeling the persistence of conditional variances, *Econometric Reviews*, 5(1), 1–50.

Fernandez, C. and Steel, M. (1998). On Bayesian Modeling of Fat Tails and Skewness. *Journal of The American Statistical Association*, 93(441), 359-371.

Giot, P., Laurent, S. (2003a). Value-at-risk for long and short trading positions. *Journal of Applied Econometrics*, 18(6), 641-663.

Giot, P., Laurent, S. (2003b). “Market risk in commodity markets: a VaR approach”. *Energy Economics*, 25(5), 435-457.

Glosten, L. R., Jaganathan, R., & Runkle, D. E. (1993). On the Relation Between the Expected Value and the Volatility of Nominal Excess Returns on Stocks, *Journal of Finance*, 48(5), 1779–1802.

Granger, C. and Poon, S. (2003). Forecasting Volatility in Financial Markets: A Review, *Journal of Economic Literature*, 41(2), 478-539.

Hansen, P.R. and Lunde, A. (2005). A forecast comparison of volatility models: does anything beat a GARCH(1,1)?, *Journal of Applied Econometrics*, 20(7), 873-889.

Jorion, P. (2000). *Value at risk: the new benchmark for managing financial risk*, 2^a Ed. New York: McGraw-Hill.

Kuester K, Mittnik S, Paolella M, (2006). Value-at-risk prediction: a comparison of alternative strategies, *Journal of Financial Econometrics*, 4(1), 53–89.

Mandelbrot, B. (1963). The variation of certain speculative prices, *Journal of Business*, 36(4), 394-419.

Nelson, D. B. (1991). Conditional Heteroskedasticity in Asset Returns: A new Approach, *Econometrica*, 59(2), 347-370.

Ñíguez, T-M. (2008). Volatility and VaR forecasting in the Madrid Stock Exchange, *Spanish Economic Review*, 10(3), 169-196.

Sener, E., Baronyan, S. and Mengütürk, L. (2012). Ranking the Predictive Performances of Value-at-Risk Estimation Methods, *International Journal of Forecasting*, 28(4), 849-873.

Tsay, R. S. (2010). *Analysis of Financial Time Series – Financial Econometrics*, John Wiley & Sons, Inc., 3ª Ed: New Jersey.

7 Anexos

7.1 Anexo A – Resultados das previsões do *VaR*

TABELA 1- Previsão *VaR* a 99% de confiança para a Altri

Violação alvo = 1% Violações alvo (nº) = 11.47			
Modelo	Distribuição	Violações atuais (nº)	Proporção de falhas (%)
GARCH	Normal	24	2.09
	t-Student	14	1.22
	GED	15	1.31
	sNormal	24	2.09
	st-Student	13	1.13
	sGED	15	1.31
IGARCH	Normal	19	1.66
	t-Student	8	0.70
	GED	11	0.96
	sNormal	19	1.66
	st-Student	9	0.78
	sGED	12	1.05
EGARCH	Normal	22	1.92
	t-Student	11	0.96
	GED	12	1.05
	sNormal	23	2.01
	st-Student	11	0.96
	sGED	14	1.22
GJR-GARCH	Normal	25	2.18
	t-Student	12	1.05
	GED	13	1.13
	sNormal	26	2.27
	st-Student	13	1.13
	sGED	12	1.05

TABELA 2- Previsão VaR a 99% de confiança para a Cimpor

Violação alvo = 1% Violações alvo (nº) = 11.47			
Modelo	Distribuição	Violações atuais (nº)	Proporção de falhas (%)
GARCH	Normal	25	2.18
	t-Student	13	1.13
	GED	7	0.61
	sNormal	24	2.09
	st-Student	8	0.70
	sGED	8	0.70
IGARCH	Normal	25	2.18
	t-Student	13	1.13
	GED	7	0.61
	sNormal	24	2.09
	st-Student	8	0.70
	sGED	7	0.61
EGARCH	Normal	26	2.27
	t-Student	9	0.78
	GED	6	0.52
	sNormal	24	2.09
	st-Student	5	0.44
	sGED	4	0.35
GJR-GARCH	Normal	26	2.27
	t-Student	10	0.87
	GED	10	0.87
	sNormal	25	2.18
	st-Student	9	0.78
	sGED	11	0.96

TABELA 3- Previsão VaR a 99% de confiança para a Mota-Engil

Violação alvo = 1% Violações alvo (nº) = 11.47			
Modelo	Distribuição	Violações atuais (nº)	Proporção de falhas (%)
GARCH	Normal	25	2.18
	t-Student	10	0.87
	GED	9	0.78
	sNormal	21	1.83
	st-Student	10	0.87
	sGED	9	0.78
IGARCH	Normal	15	1.31
	t-Student	10	0.87
	GED	9	0.78
	sNormal	13	1.13
	st-Student	10	0.87
	sGED	9	0.78
EGARCH	Normal	18	1.57
	t-Student	7	0.61
	GED	8	0.70
	sNormal	22	1.92
	st-Student	7	0.61
	sGED	10	0.87
GJR-GARCH	Normal	17	1.48
	t-Student	9	0.78
	GED	9	0.78
	sNormal	14	1.22
	st-Student	7	0.61
	sGED	9	0.78

TABELA 4- Previsão VaR a 99% de confiança para a Navigator

<p>Violação alvo = 1% Violações alvo (nº) = 11.47</p>			
Modelo	Distribuição	Violações atuais (nº)	Proporção de falhas (%)
GARCH	Normal	17	1.48
	t-Student	11	0.96
	GED	12	1.05
	sNormal	19	1.66
	st-Student	12	1.05
	sGED	12	1.05
IGARCH	Normal	15	1.31
	t-Student	8	0.70
	GED	8	0.70
	sNormal	17	1.48
	st-Student	8	0.70
	sGED	8	0.70
EGARCH	Normal	14	1.22
	t-Student	11	0.96
	GED	11	0.96
	sNormal	16	1.39
	st-Student	11	0.96
	sGED	11	0.96
GJR-GARCH	Normal	19	1.66
	t-Student	10	0.87
	GED	13	1.13
	sNormal	19	1.66
	st-Student	11	0.96
	sGED	12	1.05

TABELA 5- Previsão VaR a 95% de confiança para a Altri

<p>Violação alvo = 5%</p> <p>Violações alvo (nº) = 57.35</p>			
Modelo	Distribuição	Violações atuais (nº)	Proporção de falhas (%)
GARCH	Normal	62	5.41
	t-Student	66	5.75
	GED	60	5.23
	sNormal	64	5.58
	st-Student	68	5.93
	sGED	63	5.49
IGARCH	Normal	44	3.84
	t-Student	51	4.45
	GED	42	3.66
	sNormal	45	3.92
	st-Student	54	4.71
	sGED	46	4.01
EGARCH	Normal	56	4.88
	t-Student	60	5.23
	GED	56	4.88
	sNormal	56	4.88
	st-Student	68	5.93
	sGED	59	5.14
GJR-GARCH	Normal	59	5.14
	t-Student	61	5.32
	GED	52	4.53
	sNormal	61	5.32
	st-Student	62	5.41
	sGED	51	4.45

TABELA 6- Previsão VaR a 95% de confiança para a Cimpor

Violação alvo = 5% Violações alvo (nº) = 57.35			
Modelo	Distribuição	Violações atuais (nº)	Proporção de falhas (%)
GARCH	Normal	74	6.45
	t-Student	96	8.37
	GED	78	6.80
	sNormal	74	6.45
	st-Student	91	7.93
	sGED	79	6.89
IGARCH	Normal	74	6.45
	t-Student	96	8.37
	GED	78	6.80
	sNormal	74	6.45
	st-Student	90	7.85
	sGED	78	6.80
EGARCH	Normal	68	5.93
	t-Student	88	7.67
	GED	61	5.32
	sNormal	66	5.75
	st-Student	83	7.24
	sGED	62	5.41
GJR-GARCH	Normal	74	6.45
	t-Student	95	8.28
	GED	80	6.97
	sNormal	71	6.19
	st-Student	92	8.02
	sGED	77	6.71

TABELA 7- Previsão VaR a 95% de confiança para a Mota-Engil

Violação alvo = 5% Violações alvo (nº) = 57.35			
Modelo	Distribuição	Violações atuais (nº)	Proporção de falhas (%)
GARCH	Normal	62	5.41
	t-Student	65	5.67
	GED	55	4.80
	sNormal	58	5.06
	st-Student	61	5.32
	sGED	54	4.71
IGARCH	Normal	45	3.92
	t-Student	66	5.75
	GED	52	4.53
	sNormal	42	3.66
	st-Student	60	5.23
	sGED	52	4.53
EGARCH	Normal	59	5.14
	t-Student	59	5.14
	GED	47	4.10
	sNormal	57	4.97
	st-Student	57	4.97
	sGED	46	4.01
GJR-GARCH	Normal	54	4.71
	t-Student	64	5.58
	GED	57	4.97
	sNormal	49	4.27
	st-Student	60	5.23
	sGED	55	4.80

TABELA 8- Previsão VaR a 95% de confiança para a Navigator

<p>Violação alvo = 5%</p> <p>Violações alvo (nº) = 57.35</p>			
Modelo	Distribuição	Violações atuais (nº)	Proporção de falhas (%)
GARCH	Normal	59	5.14
	t-Student	64	5.58
	GED	56	4.88
	sNormal	60	5.23
	st-Student	64	5.58
	sGED	57	4.97
IGARCH	Normal	50	4.36
	t-Student	57	4.97
	GED	50	4.36
	sNormal	51	4.45
	st-Student	58	5.06
	sGED	51	4.45
EGARCH	Normal	61	5.32
	t-Student	63	5.49
	GED	58	5.06
	sNormal	61	5.32
	st-Student	65	5.67
	sGED	59	5.14
GJR-GARCH	Normal	58	5.06
	t-Student	62	5.41
	GED	60	5.23
	sNormal	59	5.14
	st-Student	62	5.41
	sGED	62	5.41

7.2 Anexo B – Evolução da volatilidade




FIGURA 1- Evolução da volatilidade diária da ação da Altri.




FIGURA 2- Evolução da volatilidade diária da ação da Cimpor.




FIGURA 3- Evolução da volatilidade diária da ação da Mota-Engil.




FIGURA 4- Evolução da volatilidade diária da ação da Navigator.